



REALIDADE AUMENTADA E APRENDIZADO DE MAQUINA PARA TRACKING NA MANUTENÇÃO INDUSTRIAL: UMA REVISÃO SISTEMÁTICA

¹ Rosalvo Matos Neto (CIMATEC) – rosalvo.matos@gmail.com; ² Lis Azevedo (CIMATEC) – lisazevedo3@gmail.com; ³ Ingrid Winkler (CIMATEC) – ingrid.winkler@fieb.org.br; ⁴ Valter Senna (CIMATEC) – valter.senna@gmail.com;

Resumo: A Realidade Aumentada vem sendo amplamente adotada pela Manutenção Industrial, porém as técnicas atuais de *tracking* ainda são consideradas pouco confiáveis, e uma possível solução é a adoção de técnicas de aprendizado de máquina. Diante do exposto, o objetivo deste trabalho é caracterizar, de maneira preliminar, a produção científica que aborda a relação entre o uso de *Machine Learning* e *Deep Learning* para a classificação e reconhecimento de componentes na indústria no período entre 2008 e 2018. Através de uma revisão sistemática foram identificados 14 estudos. Os resultados indicaram uso de diversas tecnologias e técnicas, os quais alcançam precisão de até 99,9%, entretanto, ainda são necessários mais estudos sobre estas técnicas.

Palavras-Chaves: Aprendizado de Máquina; Aprendizado Profundo; Tracking; Manutenção Industrial; Realidade Aumentada.

A SYSTEMATIC REVIEW OF SMART APPLICATIONS FOR CLASSIFICATION AND RECOGNITION IN INDUSTRY

Abstract: The Augmented Reality has been widely adopted by Industrial Maintenance, but the current tracking techniques are still considered unreliable, and a possible solution is the adoption of Machine Learning techniques. In view of the above, the objective of this work is to characterize, in a preliminary way, a scientific production that addresses a relation between the use of Machine Learning and Deep Learning for classification and recognition of components in the industry of the period between 2008 and 2018. Throughout the systematic review, 14 studies were identified. The results indicated several technologies and techniques, which reached an accuracy of up to 99.9%, however, further studies on these techniques are still required.

Keywords: Machine Learning; Deep Learning; Tracking; Industrial Maintenance; Augmented Reality.



1. INTRODUÇÃO

Palmarini et al [\[1\]](#) afirmam que soluções em Realidade Aumentada (RA) para apoiar a manutenção tem sido um tema de pesquisa há cerca de 50 anos. Entretanto, ainda existem alguns desafios que inviabilizam e, ou dificultam a aplicação de soluções baseadas nessas tecnologias. Um problema recorrente é o *Tracking*, que consiste em extrair informações de uma imagem ou vídeo, e a partir destas informações, reconhecer e identificar objetos.

A partir deste problema, Diante do exposto, o objetivo deste trabalho é caracterizar, de maneira preliminar, a produção científica que aborda a relação entre o uso de *Machine Learning* (ML) e *Deep Learning* (DL) para a classificação e reconhecimento de componentes na indústria no período entre 2008 e 2018. Os trabalhos serão agrupados a partir de suas tecnologias e área de aplicação, onde serão abordadas as técnicas utilizadas, métodos e precisão alcançada.

Tal análise busca contribuir para fomentar uma discussão sobre a confiabilidade destas técnicas na Indústria, através de comparações com conclusões de outros estudos, onde considerações serão feitas e sugestões para futuras pesquisas neste tema.

Este trabalho é um resultado preliminar de uma revisão mais ampla que está em andamento, realizado com o intuito de descobrir quais técnicas estão sendo aplicadas para realizar *Tracking* na indústria, a fim de estudá-las, e através dos seus resultados propor um modelo capaz de realizar *Tracking* na indústria de maneira mais confiável e robusta.

Este trabalho está organizado em cinco seções: além desta Introdução, a seção 2 aborda a Fundamentação Teórica que embasa a discussão, na seção 3 descreve-se a Metodologia utilizada; a seção 4 apresenta os Resultados e Discussões e, finalmente, na seção 5, são apresentadas as Considerações Finais e sugestões de pesquisas futuras.

1. FUNDAMENTAÇÃO TEÓRICA

Azuma *et al.* [\[2\]](#) definem um sistema de RA como a complementação do mundo real com objetos virtuais (gerados por computador) que parecem coexistir no mesmo espaço que o mundo real. Os autores também afirmam que diversos pesquisadores definem RA de maneiras diferentes, então para especificar o que seria um sistema de RA, os mesmos definem as propriedades essenciais, sendo elas:

- Combina objetos reais e virtuais em um ambiente real;
- Funciona interativamente e em tempo real;
- Alinha objetos reais e virtuais uns com os outros.

Dentre soluções existentes de RA voltadas para a Indústria, *Tracking* é um problema muito discutido [\[1\]](#). Como possíveis soluções, técnicas de Visão Computacional (VC) vem sendo aplicadas, entretanto, ainda enfrentam diversos



problemas por conta das variáveis de ambiente existentes em ambientes industriais. Tais variáveis, como iluminação e obstrução, impedem o bom funcionamento das técnicas de VC através de interfaces de RA. Diante deste problema, são criadas soluções que utilizam técnicas de ML e DL.

ML foi apresentada por Samuel [3] como a capacidade de computadores aprenderem sem serem explicitamente programados. Com o seu uso, computadores tornam-se capazes de reconhecer padrões a partir de dados brutos e extrair informações de maneira autônoma.

DL, assim como o ML é uma tecnologia que permite ao computador aprender de maneira autônoma. Segundo [4], DL foi desenvolvido principalmente, para resolver problemas de performance durante as fases de treinamento e validação que ML apresenta. Uma solução proposta foi a possibilidade de gerar camadas de informações extraídas autonomamente, de acordo com os dados brutos, permitindo uma análise destes mais robusta. ML utiliza um número de camadas pré-definido, limitando a quantidade de informações extraídas.

2. METODOLOGIA

Nos próximos parágrafos, são descritos os dois passos realizados para pesquisa e construção deste trabalho.

3.1. Etapa de Planejamento

Para realizar este estudo, foi definido um conjunto de palavras chaves, período, tipos de trabalho e critérios para inclusão e exclusão. Tais filtros foram selecionados de forma que os resultados obtidos fossem correlatos ao assunto proposto e reflitam o que está sendo estudado e utilizado nos últimos anos.

A base científica selecionada para a concepção deste estudo foi ScienceDirect (www.sciencedirect.com).

O software utilizado para gerenciamento dos resultados obtidos foi Mendeley (www.mendeley.com), por conta de sua interface amigável e de algumas funcionalidades que auxiliam no estudo e escrita, como a geração automática de referências e compartilhamento de documentos online.

3.2. Etapa de pesquisa

A *string* de busca utilizada para esta pesquisa foi:

("Machine Learning" OR "Deep Learning") AND ("Object Classification" OR "Feature Extraction") AND ("Industry" OR "Industries" OR "Industrial")

Este conjunto de palavras foi selecionado para que os resultados refletissem os trabalhos que utilizam ML e DL para realizar *Tracking* na Indústria. As palavras "*Object*



Classification” e *Feature Extraction*” foram utilizadas ao invés de *Tracking*, pois apresentam resultados mais específicos, já que *Tracking* além de reconhecimento e classificação, também trata outras funcionalidades, como rastreamento.

O período foi definido como os últimos dez anos (2008-2018) com a finalidade de expor as técnicas do estado da arte. A coincidência das palavras foi verificada nos campos Título, Resumo e Palavras-chave de cada artigo para que fossem selecionados somente artigos que realmente fossem deste assunto, eliminando outros que utilizassem qualquer uma destas palavras em um contexto diferente.

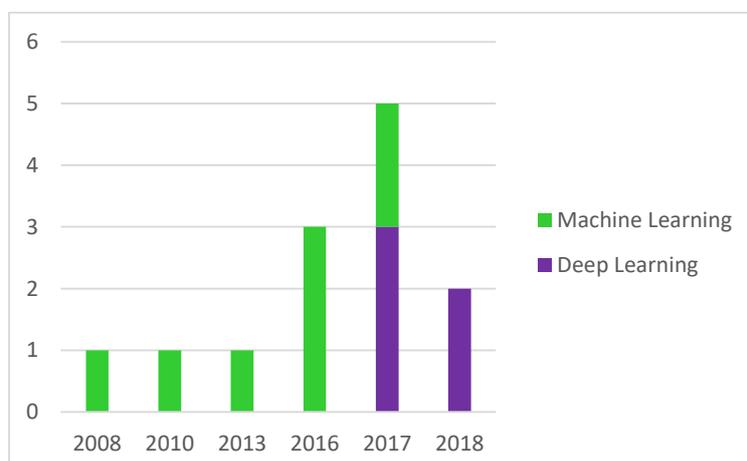
Os critérios de inclusão e exclusão foram levantados para refinar os resultados obtidos, selecionando os que realmente se aprofundem no assunto de interesse e os parcialmente relacionados com a pesquisa (atendem alguns dos critérios). Os critérios para seleção dos trabalhos relacionados e parcialmente relacionados foram:

- Que se aprofunda em aplicar técnica de extração de características;
- Que se aprofunda em realizar classificação ou reconhecimento;
- Realizar testes em ambiente industrial.

3. RESULTADOS E DISCUSSÃO

Os trabalhos identificados foram analisados e separados em três grupos, ML, DL e *Deep Machine Learning* (DML), definidos a partir da tecnologia utilizada pelos trabalhos para solucionar problemas propostos. A identificação e separação dos estudos nesses três grupos permite apontar qual está sendo mais utilizada e como se comportam através do tempo. Embora tenham sido identificados três grupos, DML não foi citada por qualquer outro autor após ser proposta, ressaltando que tal conclusão foi obtida através dos resultados presentes nesta revisão, e que é possível que tal tecnologia tenha sido utilizada por outros autores em outras áreas, ou até mesmo com termos que não estão cobertos pelos utilizados nesta revisão. Por conta desta baixa visibilidade, DML não aparece na Figura 1 e nas análises realizadas.

Figura 1. Tecnologias distribuídas por Ano





A partir da Figura 1 é analisado que soluções que utilizam ML já estavam sendo estudadas em 2008, e foram crescendo através dos anos. Entretanto, em 2017 DL se apresenta com grande força, tendo exclusividade em resultados no ano de 2018, levando em consideração que os trabalhos estudados para esta revisão foram obtidos no primeiro trimestre de 2018. Tal comportamento pode insinuar que a utilização de DL para tal prática se apresente mais propensa do que ML para soluções na indústria com classificação e reconhecimento.

Os resultados demonstraram que, por mais que soluções de aprendizado de máquina para a indústria consigam taxas de precisão de 99,9% [5], por exemplo, estas técnicas ainda são descritas como não confiáveis ou adequadas [2]. Uma razão para tal conclusão poderia ser a aplicabilidade destas soluções, entendendo que o ambiente industrial é confuso, existe a possibilidade de que a técnica não funcione em todos, ou caso funcione, tenha sua precisão alterada. Para solucionar este problema em questão, é necessário que os autores estudem e explorem mais ambientes Industriais e consigam criar soluções aplicáveis a ambientes distintos.

A análise dos trabalhos foi agrupada em 4 categorias que representam suas áreas de aplicação. Tal agrupamento foi realizado com o intuito de comparar melhor as técnicas e resultados. As categorias identificadas foram, Extração de Características, Classificação de Qualidade, Monitoramento de Estado e Inspeção de Defeitos.

4.1 Extração de Características

Por mais que a maioria das técnicas utilizadas para Classificação e Reconhecimento através de imagens realizem extrações de características, entender imagens e extrair informações é algo tão crítico na Indústria, que existem pesquisas que focam somente esta falha.

Dentre os trabalhos analisados, três deles estudam sobre extração de características, sendo todos do mesmo ano (2017) e trabalhando com extração através de imagens. Horn *et al.* [6] sugerem a utilização de *Convolutional Neural Networks* (CNN), ressaltando as dificuldades em realizar extrações de características em ambientes Industriais, o autor compara sua técnica com outras propostas.

Os outros autores [7, 8], propõem métodos próprios para auxiliar no processo de classificação, ambos tendo como foco melhorar a precisão em extrair características. Ambos utilizam ML e exibem seus resultados através de Tabelas Confusão.

4.2 Classificação de Qualidade

Nesta categoria, os autores buscam auxiliar na inspeção de qualidade, qualificando objetos a partir de imagens, som ou modelos 3D. Esta foi a categoria com maior número de trabalhos, e um fato interessante é a distribuição temporal dos resultados, onde o primeiro em 2008, consegue uma precisão de 76% [9], e ao passar do tempo, a mesma vai aumentando.



Em 2013 Pinto, Rocha e Moreira [10], propõem uma abordagem alcançando uma precisão de 98,9%. O autor constata que luminosidade é um grande problema, e sugere a utilização de lasers no lugar de câmeras. Siuly *et al.* [11], utilizam pulsos THz (Terahertz), para criar um método capaz de diferenciar amostras de pó. São utilizadas diversas técnicas combinadas, se destacando *K-Nearest Neighbors* (kNN) e *Multinomial Logistic Regression* (MLR). Uma precisão de 90,19% é alcançada.

O trabalho mais recente [12], alcança uma precisão de 99,87%, aplicando uma fusão entre kNN e *Stacked Denoising AutoEncoder* (SDAE). O autor explica como uma técnica auxilia a outra no processo de classificação, e por fim realiza um teste de *benchmark* para mostrar a precisão alcançada pelo seu método.

4.3 Monitoramento de Estado

As técnicas de monitoramento de estado, em sua maioria oferecem abordagens para monitoração e predição de dano em componentes. Nesta categoria são abordadas soluções que utilizam emissão acústica para identificar corrosão em componentes [13], e outras baseadas em imagens.

Kolodziejczyk *et al.* [14] apresentam soluções semelhantes, onde câmeras estáticas são mantidas observando componentes e calculando possíveis alterações. Wang, Song e Chen [5] alcançam uma precisão de 99,9% utilizando a combinação de CNN e *Deep Neural Network* (DNN).

Na, Jeon e Lee [15] apresentam um estudo onde sua técnica prediz a dispersão de gases tóxicos em tempo real, com o viés de reduzir danos. O autor trabalha com algoritmos de regressão e DNN, utilizando dinâmica dos fluidos, realiza análises para probabilidade de mortes. O resultado alcançado é de um erro quadrado de 0.00246, para a predição de probabilidade de mortes.

4.4 Inspeção de Defeitos

Foram encontrados apenas dois resultados para esta categoria, ambos de 2016. O primeiro [16] é interessante, pois o autor propõe uma nova abordagem, a qual ele denomina DML. O autor constata que ML tem diversas limitações e que esta nova abordagem soluciona a maioria deles. Seu trabalho tem o propósito de extrair características de imagens e encontrar defeitos em componentes industriais, auxiliando no processo de inspeção. A precisão alcançada foi de 99,2%.

Wang e Xu [17] utilizam vídeos com multidões como insumos, porém realiza comparações com a indústria. O autor cria um algoritmo que trabalha em tempo real, extraindo características dos vídeos e trabalhando a partir delas. O autor não comenta sobre a precisão alcançada pelo algoritmo, mas demonstra alguns resultados através de tabelas.



4. CONSIDERAÇÕES FINAIS

Após a leitura e análise dos trabalhos identificados nesta revisão preliminar, é observado que existem diversas soluções para a Indústria que utilizam artifícios computacionais para auxiliar em processos, sejam estes de produção, segurança entre outros. É percebido um avanço na precisão ao passar dos anos, entretanto tais soluções são aplicadas somente em um único ambiente. Também é percebido que a maior parte das soluções utiliza alguma variação de Redes Neurais e kNN, em grande parte combinando estas com outras técnicas.

Como proposta de solução para este problema, é necessário que os autores estudem e explorem mais ambientes industriais e consigam criar soluções aplicáveis a ambientes distintos sem que a acurácia seja afetada.

Como futuros passos, esta revisão será estendida a mais bases científicas, e é sugerido que avance na proposição de um modelo que utilize ML e DL para melhorar a acurácia do *Tracking* de RA na indústria de forma confiável, independente do ambiente de atuação.

Agradecimentos

Os autores agradecem ao Grupo de Pesquisa em Realidade Aumentada e Visão Computacional para Inovação na Indústria (CNPQ), à EMBRAPPII pelo auxílio financeiro da bolsa de formação e desenvolvimento tecnológico concedida e à FAPESB pelo auxílio financeiro da bolsa de Iniciação Científica concedida.



5. REFERÊNCIAS

¹ AZUMA, R. BAILLOT, Y. BEHRINGER, R. FEINER, S. JULIER, S. MACINTYRE, B. Recent Advances in Augmented Reality. **IEEE Computer Society**, p. 34-47, 2001.

² PALMARINI, R., ERKOYUNCU, J. A., ROY, R., TORABMOSTAEDI, H. A systematic review of augmented reality applications in maintenance. **Robotics and Computer-Integrated Manufacturing**, v. 49, p. 215-228, 2018.

³ SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of Research and Development**, v. 3(3), p. 210–229, 1959.

⁴ GOODFELLOW, I. BENGIO, Y. COURVILLE, A. **Deep Learning**. Massachusetts: The MIT Press, 2016.

⁵ WANG, Z., SONG, C., & CHEN, T. Deep learning based monitoring of furnace combustion state and measurement of heat release rate. **Energy**, v. 131, p. 106–112, 2017.

⁶ HORN, Z. C., AURET, L., MCCOY, J. T., ALDRICH, C., & HERBST, B. M. Performance of Convolutional Neural Networks for Feature Extraction in Froth Flotation Sensing. **IFAC-PapersOnLine**, v. 50(2), p. 13–18, 2017.

⁷ LEFKOVITS, S., & LEFKOVITS, L. Gabor Feature Selection Based on Information Gain. **Procedia Engineering**, v. 181, p. 892–898, 2017.

⁸ DONG, Y., & QIN, S. J. Dynamic latent variable analytics for process operations and control. **Computers and Chemical Engineering**, v. 114, p. 69-80, 2017.

⁹ WAEGEMAN, W., COTTYN, J., WYNS, B., BOULLART, L., DE BAETS, B., VAN LANGENHOVE, L., & DETAND, J. Classifying carpets based on laser scanner data. **Engineering Applications of Artificial Intelligence**, v. 21(6), p. 907–918, 2008.



- ¹⁰ PINTO, A. M., ROCHA, L. F., & MOREIRA, A. P. Object recognition using laser range finder and machine learning techniques. **Robotics and Computer-Integrated Manufacturing**, v. 29(1), p. 12–22, 2013.
- ¹¹ SIULY, YIN, X., HADJILOUCAS, S., & ZHANG, Y. Classification of THz pulse signals using two-dimensional cross-correlation feature extraction and non-linear classifiers. **Computer Methods and Programs in Biomedicine**, v. 127, p. 64–82, 2016.
- ¹² ZHANG, Z., JIANG, T., LI, S., & YANG, Y. Automated feature learning for nonlinear process monitoring – An approach using stacked denoising autoencoder and k-nearest neighbor rule. **Journal of Process Control**, v. 64, p. 49–61, 2018.
- ¹³ MORIZET, N., GODIN, N., TANG, J., MAILLET, E., FREGONESE, M., & NORMAND, B. Classification of acoustic emission signals using wavelets and Random Forests: Application to localized corrosion. **Mechanical Systems and Signal Processing**, v. 70–71, p. 1026–1037, 2016.
- ¹⁴ KOLODZIEJCZYK, T., TOSCANO, R., FOUVRY, S., & MORALES-ESPEJEL, G. Artificial intelligence as efficient technique for ball bearing fretting wear damage prediction. **Wear**, v. 268(1–2), p. 309–315, 2010.
- ¹⁵ NA, J., JEON, K., & LEE, W. B. Toxic gas release modeling for real-time analysis using variational autoencoder with convolutional neural networks. **Chemical Engineering Science**, v. 181, p. 68–78, 2018.
- ¹⁶ WEIMER, D., SCHOLZ-REITER, B., & SHPITALNI, M. Design of deep convolutional neural network architectures for automated feature extraction in industrial inspection. **CIRP Annals**, v. 65(1), p. 417–420, 2016.
- ¹⁷ WANG, J., & XU, Z. Spatio-temporal texture modelling for real-time crowd anomaly detection. **Computer Vision and Image Understanding**, v. 144, p. 177–187, 2016.
- ¹⁸ AFFONSO, C., ROSSI, A. L. D., VIEIRA, F. H. A., & DE CARVALHO, A. C. P. de L. F. Deep learning for biological image classification. **Expert Systems with Applications**, v. 85, p. 114–122, 2017.